

Primljen / Received: 18.9.2013.

Ispravljen / Corrected: 29.11.2013.

Prihvaćen / Accepted: 27.12.2013.

Dostupno online / Available online: 10.1.2014.

# Regresijsko modeliranje onečišćenja prometnom bukom

## Autori:

**Yugananth Pachiappan**, dipl.ing.građ.

Anna Sveučilište

Chennai, TamilNadu, India

[yugananthtnp@gmail.com](mailto:yugananthtnp@gmail.com)Izv.prof.dr.sc. **Baskar Govindaraj**, dipl.ing.građ.

Institut za promet i tehnologiju prometa

Zavod za građevinarstvo

Erode, TamilNadu, India

[baskar@irttech.ac.in](mailto:baskar@irttech.ac.in)

Prethodno priopćenje

**Yugananth Pachiappan, Baskar Govindaraj**

## Regresijsko modeliranje onečišćenja prometnom bukom

Buka se razlikuje od pojava koje dovode do onečišćenja zraka, vode i tla jer ne ostavlja nikakav trag koji bi poslužio kao stalni podsjetnik na neugodu koju uzrokuje. U SAD-u, Velikoj Britaniji i Bangkoku koriste se modeli kao što su FHWA, CORTN, STOP i GO. Međutim, do sada nije razvijen konačan model za indijske uvjete cestovnog prometa. U ovom se radu prikazuje novi model za predviđanje prometne buke zbog neprekinutog odvijanja cestovnog prometa po četverotračnim cestovnim prometnicama u Indiji. Ovaj model, utemeljen na regresijskoj analizi, može se djelotvorno koristiti kao podrška pri donošenju odluka o predviđanju prometne buke na indijskim cestama.

### Ključne riječi:

promet, prometna buka, matematičko modeliranje, emisija buke

Preliminary note

**Yugananth Pachiappan, Baskar Govindaraj**

## Regression modelling of traffic noise pollution

Noise is distinctive in comparison to pollutants like air, water and soil. It does not leave any residual evidence that would serve as a continuing reminder of its unpleasantness. Models like FHWA, CORTN, STOP and GO are used for traffic noise prediction in the US, UK, and Bangkok, respectively. But so far, no definite model has been developed for Indian road conditions. A new road traffic noise prediction model for uninterrupted four-lane Indian roads, developed using the regression analysis, is presented in this paper. This model can be effectively used as a decision-supporting tool for road traffic noise prediction on Indian roads.

### Key words:

transport, traffic noise, mathematical modelling, noise emission

Vorherige Mitteilung

**Yugananth Pachiappan, Baskar Govindaraj**

## Regressionsmodellierung von Verkehrslärm

Lärm ist spezifisch im Vergleich zu anderen Verschmutzungen von Luft, Wasser und Boden, da er keine verbleibenden Rückstände hinterlässt, die kontinuierlich an seine Unannehmlichkeit erinnern. Modelle wie z.B. FHWA, CORTN, STOP und GO werden für die Vorhersage von Verkehrslärm in den USA, Großbritannien und Bangkok angewandt. Bisher ist kein bestimmtes Vorhersagemodel für Indische Straßenbedingungen entwickelt worden. In dieser Arbeit wird ein neues, auf der Regressionsanalyse beruhendes Model zur Lärmvorhersage für ununterbrochene Vierspurstraßen in Indien vorgeschlagen, das als effektives Instrument zur Entscheidungsunterstützung in Verkehrslärmvorhersagen für Indische Straßen angewandt werden kann.

### Schlüsselwörter:

Transport, Verkehrslärm, mathematische Modellierung, Lärmemission

## 1. Uvod

Mreža autocesta je najvažniji dio gospodarstva svake države pa se tako može usporediti s ulogom nervnog sustava u ljudskom tijelu. Indijska cestovna mreža ima više od 4,32 milijuna kilometara cestovnih prometnica. To je druga po veličini cestovna mreža na svijetu, pa tako slijedi odmah nakon cestovne mreže SAD-a koja ima otprilike 7 milijuna kilometara cesta. Na indijskoj je mreži teretni promet zastupljen s oko 65 % dok se preostali dio od 35 % odnosi na putnički promet, pri čemu broj automobila raste po stopi otprilike od 12 %. Isto tako, cestovni promet raste za otprilike 10 %, u odnosu na standardnu stopu rasta od 7,5 %. Tako brz porast broja cestovnih vozila u Indiji uvjetuje i odgovarajući razvoj cestovne mreže, što dovodi do razvoja infrastrukture, industrijalizacije i urbanizacije. Takav sveobuhvatan razvoj dovodi do zakrčenosti cestovne mreže i do raznih vrsta onečišćenja. Onečišćenje zraka, ozljede koje se javljaju u cestovnom prometu, promjena klime i onečišćenje bukom su najveći problemi koji se povezuju s razvojem prometa. Od tih problema, najmanje se pažnje pridaje onečišćenju bukom, pa to pitanje u velikoj mjeri zanemaruju inženjeri, planeri i političari mnogih zemalja. Ako je usporedimo s drugim onečišćivačima, buka je jedinstvena jer, za razliku od onečišćenja zraka, vode ili tla, ona nam ne pruža posljedične dokaze koji bi poslužili kao trajni podsjetnik na njen štetan utjecaj.

Neodgovarajuća razina buke negativno utječe na fizičke i psihičke karakteristike osoba izloženih onečišćenju bukom. Ovisno o trajanju i stupnju izloženosti, utjecaji buke na ljudsko zdravlje i komfor mogu se podijeliti na četiri kategorije: fizički utjecaji kao što su oštećenje sluha; fiziološki utjecaji kao što su visoki krvni tlak, srčana aritmija i čir; psihički utjecaji kao što su primjerice nesanica i poremećaji spavanja, pretjerana osjetljivost i stres; te konačno utjecaji na radnu sposobnost kao što su smanjenje produktivnosti i pogrešno razumijevanje onoga što čujemo [1].

Tablica 1. prikazuje standarde za vanjsku buku koji se u Indiji primjenjuju za industrijska, komercijalna i stambena područja te za područja niske razine buke, i to kako po danu tako i po noći, a prema uputama Središnjeg odbora za kontrolu onečišćenja koji djeluje u sklopu indijske vlade.

Tablica 1. Indijski standardi za vanjsku buku

Područje	Granične vrijednosti u dB(A)	
	Dan (06:00 - 22:00)	Noć (22:00 - 06:00)
1. Industrijsko područje	75	70
2. Komercijalno područje	65	55
3. Stambeno područje	55	45
4. Zona niske razine buke	50	40

Prometna se buka može izmjeriti ali i predvidjeti. Mjerenja buke su složena i dugotrajna. Osim toga, buka se ne može mjeriti u

fazi projektiranja [2]. Prilikom projektiranja novih cesta, trebaju se koristiti modeli za predviđanje prometa da bi se postigli prihvatljivi uvjeti boravka u industrijskim, komercijalnim i stambenim područjima, te u zonama niske razine buke. Osim toga, analizom i modeliranjem prometne buke omogućuje se jednostavnije planiranje ekološki prihvatljivih cestovnih prometnica [3]. Odgovarajući proračunski modeli mogu se koristiti za razvoj raznih tehnologija za kontrolu buke u razdoblju prije samog građenja, i za definiranje najdjelotvornijih zaštitnih mjera u fazi projektiranja. Primjenom takvih postupaka izbjegava se potreba za odgovaranjem na pritužbe osoba koje žive u blizini ceste u razdoblju nakon gradnje prometnice, tj. za provođenjem skupih naknadnih zaštitnih mjera. Pokazalo se da je prevencija uvijek bolja od liječenja [4]. Općenito uzevši, zvuk može biti izuzetno varijabilan. Uzimajući u obzir sposobnost ljudskog uha da reagira na razne jačine zvuka, za mjerenje razine zvuka korišteni su filtri za ponderiranje. Formulirana je ponderirana razina zvuka A da bi se što točnije okarakterizirao odziv ljudskog uha na varijacije zvuka. Takova ponderirana A-vrednovana ekvivalentna razina buke, koja se iskazuje kao dB(A), danas je uobičajena ljestvica za mjerenje razine zvuka u sektoru prometa [5].

Razina buke koju stvaraju vozila u cestovnom prometu izuzetno varira u vremenu. Da bi se ova problematika pojednostavnila, usvojen je univerzalno prihvaćeni parametar Leg, energetski ekvivalent razine buke, kako bi se dobila logična statistička prosječna razina buke koja opisuje istu magnitudu izloženosti buci u razdoblju mjerenja. Dakle Leq može zamijeniti razne razine buke s jedinstvenom vrijednošću razine buke koja se izražava u dB(A) [6]. U tom kontekstu, ovaj rad predstavlja pokušaj predviđanja ekvivalentne razine buke za kontinuirani četverotračni promet na cesti Salem-Cochin (NH 47) u pokrajini Tamil Nadu u Indiji.

## 2. Ciljevi istraživanja

Osnovni ciljevi su:

- mjerenje prevladavajuće razine buke generirane prometnim tokom u području ispitivanja,
- razvoj multilinearne regresijskog modela za predviđanje prometne buke,
- ocjena razine prilagodbe predloženog modela,
- razvoj jednadžbi za mjerenje buke vozila po kategoriji vozila a na bazi trenutačne brzine,
- izrada korelacijske studije onečišćenja bukom za razne tokove prometa i cestovne parametre.

## 3. Materijali i metodologija

### 3.1. Područje ispitivanja

Prometnica Salem – Cochin je značajna državna autocesta (NH 47) s gustim prometom koja povezuje indijske pokrajine Tamil Nadu i Kerala. Radi se o autocesti s četiri traka i s

razdjelnim pojasom širine 4,5 m. U ovom su istraživanju prometna buka i ostali parametri mjereni na ravnom potezu ceste s neprekinutim prometnim tokom bez bilo kakvih križanja, građevina ili poprečnih odvodnih građevina kao što su propusti i mostovi u pojasu od 500 m sa svake strane prometnice. Četiri poteza koja udovoljavaju ovim kriterijima, a to su km 82/2, km 73/10, km 68/8 i km 60/10, ocijenjena su povoljnima za mjerenja u okviru ovog istraživanja te za izradu modela. Još jedan potez na istoj prometnici, km 78/10, korišten je za provjeru modela. Za sve spomenute lokacije karakteristična je kvalitetna asfaltna kolnička konstrukcija, s dobrom voznom površinom. Ti su cestovni potezi prikazani na preglednoj situaciji (slika 1.). Svi podaci su prikupljeni pod povoljnim meteorološkim uvjetima, bez utjecaja vjetrova i kiše.



Slika 1. Pregledna situacija s analiziranim dionicama na autocesti NH-47

### 3.2. Vrijeme analize

Svi su podaci prikupljeni u vremenu od 6:00 do 19:00 sati. Ponašanje vozila i vozača može varirati ovisno o smjeru putovanja. Stoga, da bi se dobili što točniji podaci, mjerenja su obavljena na obje strane ceste u svakom satu unutar razdoblja analize.

Prvi niz mjerenja obavljen je na lijevoj strani ceste u prvih 20 minuta, a u idućih 10 minuta uređaji su prebačeni s lijeve na desnu stranu prometnice. Sljedeći niz mjerenja obavljen je na desnoj strani ceste također u vremenu od 20 minuta. Nakon toga je slijedilo razdoblje od 10 minuta u kojem su uređaji prebačeni s desne na lijevu stranu ceste. Isti je postupak proveden i u sljedećem satu.

Dakle, na svakoj su lokaciji obavljena po četiri niza mjerenja (dva niza mjerenja na lijevoj strani i dva niza mjerenja na desnoj strani). Ukupno je obavljeno 16 mjerenja na 4 lokacije. Preostalo je vrijeme korišteno za premještanje i učvršćivanje uređaja, pribora itd. na zadanoj lokaciji.

### 3.3. Terenska ispitivanja

Imajući na umu spomenute ciljeve, definiran je program terenskih ispitivanja da bi se odredili sljedeći parametri:

- intenzitet prometa,
- trenutačna brzina za svaku kategoriju vozila,
- razina buke,
- vanjska temperatura,
- temperatura na površini kolnika i
- relativna vlaga.

### 3.4. Brojenje prometa

Broj vozila koja su sudjelovala u prometu na lokaciji ispitivanja u smjeru mjerenja i u suprotnom smjeru određen je ručno u skladu sa standardnim postupkom ICK-a (Indijskog cestovnog kongresa). U prometu na ispitivanom području sudjelovale su sljedeće kategorije vozila: vozila na dva kotača, vozila na tri kotača, osobna vozila, terenska vozila, dostavna vozila, autobusi, laka komercijalna vozila i kamioni.

### 3.5. Mjerenje trenutačne brzine

Mjerenja trenutačne brzine obavljena su za svaku kategoriju vozila u smjeru ispitivanja pomoću ručnog radarskog brzinomjera. Rezultati mjerenja su nakon očitavanja ručno zabilježeni u odgovarajućem formatu. Za svaku kategoriju vozila obavljen je najveći mogući broj mjerenja trenutačne brzine.

### 3.6. Razina buke

Razina buke mjerena je u decibelima pomoću mjerača razine buke (Lutron, model SL-4010) koji registrira zvuk otprilike na isti način kao i ljudsko uho. Razina zvuka prikazana je u digitalnom formatu. Da bi se smanjio utjecaj vjetrova, na vrh mikrofona postavljena je posebna zaštita od spužve. Svakodnevno je mjerach razine buke baždaren prije početka mjerenja pomoću standardnog baždarnog uređaja, a pritom je u potpunosti uzet u obzir postupak koji preporučuje proizvođač. Vrijednost buke očitana je nakon svakog prolaza vozila pored mjerača. Vrijednosti buke unosile su se ručno u odgovarajući formular. Za svaku kategoriju vozila obavljen je najveći mogući broj očitavanja buke. U literaturi nalazimo vrlo raznovrsne podatke o odabiru zone mjerenja. Zbog toga su poduzete sljedeće mjere opreza da bi očitavanja razine buke bila što točnija:

- Visina na kojoj se postavlja mjerach razine buke iznad površine ceste: 1.20 m.
- Udaljenost ispitivača od mjerača razine buke: 0,50 m.
- Vjetrobran je postavljen da bi se eliminirali utjecaji vjetrova.
- Udaljenost mjerača razine zvuka od ruba kolnika: 1,50 m.
- Mjerach razine buke postavljen je na mjesto na kojem nema nikakvih prepreka poput drveća, visokih zgrada, parkiranih vozila itd.

Tablica 2. Interkorelacijska matrica

Variable	Leq	Q	P <sub>t</sub>	S <sub>t</sub>	S <sub>o</sub>	T <sub>a</sub>	T <sub>s</sub>	H
Leq	1	-0,30511	0,376971	0,426739	0,607037	-0,4575	-0,62876	0,623723
Q	-0,30511	1	0,31317	-0,0999	-0,32303	0,594412	0,559956	-0,61668
P <sub>t</sub>	0,376971	0,31317	1	0,010799	0,02061	0,445622	0,296381	-0,33537
S <sub>t</sub>	0,426739	-0,0999	0,010799	1	0,854109	-0,25162	-0,35743	0,328226
S <sub>o</sub>	0,607037	-0,32303	0,02061	0,854109	1	-0,39015	-0,54079	0,575244
T <sub>a</sub>	-0,4575	0,594412	0,445622	-0,25162	-0,39015	1	0,882062	-0,89493
T <sub>s</sub>	-0,62876	0,559956	0,296381	-0,35743	-0,54079	0,882062	1	-0,92504
H	0,623723	-0,61668	-0,33537	0,328226	0,575244	-0,89493	-0,92504	1

Ekvivalentna razina buke izračunana je pomoću standardne formule, a na temelju rezultata ispitivanja:

$$Leq = 10 \cdot \log_{10} [10^{L1/10} + 10^{L2/10} + 10^{L3/10} + \dots + 10^{Ln/10}] / n$$

gdje su L1, L2, L3, ....., Ln pojedinačna očitavanja razine buke u dB(A).

### 3.7. Ostali parametri

Temperatura na površini asfaltnog kolnika određena je pomoću ručnog laserskog termometra. Rezultati očitavanja uneseni su u zadanom formatu. Stolni digitalni termo-higrometar korišten je za mjerenja vanjske temperature i relativne vlažnosti na lokacijama ispitivanja. U svakom razdoblju ispitivanja, vrijednosti temperature na površini kolnika, vanjske temperature i relativne vlage mjerene su na početku i na kraju ispitivanja da bi se tako dobile pouzdane prosječne vrijednosti.

## 4. Matematička formulacija

### 4.1. Interkorelacijska matrica parametara

Na temelju očitanih podataka, analizirana je korelacija između varijabli da bi se ustanovio stupanj povezanosti ovisnih varijabli s neovisnim varijablama te razina povezanosti između neovisnih varijabli. Promatrana korelacija varijabli prikazana je u tablici 2.

### 4.2. Model za predviđanje ekvivalentne razine buke

Na temelju podataka očitanih u raznim vremenskim intervalima, te na bazi ekvivalentne razine buke, obavljena je analiza pomoću programa DATAFIT (Verzija 9), te je izrađen odgovarajući model za predviđanje cestovne buke u uvjetima neprekinutog toka prometa na cesti s četiri prometna traka. Ekvivalentna razina buke u dB(A):

$$Leq = 72.249 - 0.0058 \cdot Q + 0.2535 \cdot P_t + 0.0606 \cdot S_t + 0.0119 \cdot S_o + 0.0273 \cdot T_a - 0.058 \cdot T_s + 0.0638 \cdot H$$

(R<sup>2</sup> = 0.809)

gdje je:

- Q - ukupan broj vozila u smjeru mjerenja,
- P<sub>t</sub> - postotak vozila s dva kotača u smjeru mjerenja,
- S<sub>t</sub> - prosječna trenutačna brzina vozila s dva kotača u smjeru mjerenja, u km/h,
- S<sub>o</sub> - prosječna trenutačna brzina svih vozila osim vozila s dva kotača u smjeru mjerenja, u km/h,
- T<sub>a</sub> - prosječna vanjska temperatura u °C,
- T<sub>s</sub> - prosječna temperatura na površini kolnika u °C,
- H - relativna vlaga u %,
- R<sup>2</sup> - koeficijent korelacije.

Na svakoj vrsti ceste smatra se promet vozila s dva kotača osnovnim utjecajnim faktorom pri određivanju prometne buke. Stoga se u ovom modelu poseban naglasak stavlja na postotak vozila s dva kotača i na njihovu brzinu kretanja.

## 5. Rezultati i rasprava

Na temelju gornje formule izračunana je ekvivalentna razina buke za uvjete neprekinutog prometnog toka na cestovnoj prometnici s četiri traka. Vrijednosti Leq (očitano) i Leq (izračunano) za promatrane lokacije iskazane su u tablici 3. Kao što je navedeno, ukupno je obavljeno 16 mjerenja na 4 lokacije.

Hi-kvadrat test za ocjenu prilagodbe primijenjen je za određivanje stupnja podudarnosti između očitane raspodjele i izračunane raspodjele u ispitanom uzorku. U obzir je uzeta nulta hipoteza,  $\mu = 0$ , što znači da je srednja vrijednost razlika između parova očitane buke i predviđene buke jednaka nuli. Izračunana vrijednost Hi-kvadrata manja je od očitane vrijednosti za 5 %, prema stupnju važnosti. Stoga je usvojena nulta hipoteza i zaključeno je da nema bitne razlike između očitanih i predviđenih razina buke. Prema tome, ovaj se model može djelotvorno koristiti za predviđanje vrijednosti cestovne buke u vrijednostima Leq u Indiji u uvjetima neprekinutog prometa na cestama s četiri traka. Vrijednosti buke očitane na četiri analizirane lokacije prikazane su u tablici 4.

Tablica 3. Leq (očitano) u odnosu na Leq (izračunano)

Mjerenje	Leq (očitano) [dB(A)]	Leq (izračunano) [dB(A)]	Odstupanje [%]
1	84,02	83,685	0,399
2	85,47	84,562	1,062
3	82,81	84,604	-2,167
4	89,16	88,358	0,899
5	83,10	84,003	-1,086
6	81,73	82,528	-0,977
7	83,27	83,195	0,090
8	82,79	82,457	0,402
9	81,24	81,925	-0,843
10	83,66	82,360	1,554
11	80,63	81,579	-1,177
12	82,26	80,844	1,721
13	80,30	81,224	-1,151
14	81,65	81,784	-0,164
15	81,54	80,597	1,156
16	81,62	81,544	0,093

Ova analiza pokazuje da prosječna razina buke na analiziranim lokacijama u uvjetima neprekinutog prometa na cesti s četiri traka iznosi 79,71 dB(A) uz standardno odstupanje od 5,20 dB(A), što je više od prihvatljive granice od 75 dB(A) koju je definiralo indijsko Ministarstvo okoliša i šuma za industrijska područja.

### 5.1. Provjera modela

Podaci su očitani drugog dana na km 78/10 iste ceste (peta lokacija) i pritom je primijenjen isti postupak za prikupljanje

Tablica 5. Očitane i predviđene ekvivalentne razine buke dobivene prilikom provjere modela

Red. br.	Leq (očitano) [dB(A)]	Leq (izračunano) [dB(A)]	Odstupanje [%]
1	83,09	82,954	0,164
2	82,59	83,367	-0,941
3	79,73	82,391	-3,338
4	81,25	81,532	-0,347
5	81,02	81,752	-0,903
6	81,64	81,517	0,151
7	82,52	80,115	2,914
8	80,98	78,886	2,586
9	80,34	79,503	1,042
10	81,11	79,149	2,418
11	79,34	77,814	1,923
12	79,99	78,425	1,956
13	79,92	77,792	2,663
14	80,66	78,971	2,094

podataka. Na petoj je lokaciji očitano ukupno četrnaest nizova podataka. Tablica 5. prikazuje usporedbu očitanih i predviđenih vrijednosti ekvivalentnih razina buke. Kako predviđene vrijednosti odstupaju za manje od 5 %, ovaj se model može uspješno koristiti za predviđanje prometne buke u uvjetima neprekinutog prometa na cestama s četiri traka u Indiji.

### 5.2. Utjecaj trenutačne brzine vozila na razinu buke

Kod većine cestovnih vozila, brzina vozila je značajan faktor za određivanje razine buke. Trenutačna brzina vozila izmjerena na četiri analizirane lokacije prikazana je u tablici 6.

Tablica 4. Očitane razine buke na analiziranim lokacijama

Lokacija (autocesta NH 47)	Minimalna razina buke [dB(A)]	Maksimalna razina buke [dB(A)]	Srednja razina buke [dB(A)]	Standardno odstupanje razina buke [dB(A)]
km 82/2	69,60	105,20	81,48	5,26
km 73/10	64,50	94,40	80,18	5,18
km 68/8	62,60	96,90	79,23	5,16
km 60/10	65,90	96,40	78,57	4,84

Tablica 6. Trenutačna brzina vozila na analiziranim lokacijama

Lokacija (autocesta NH 47)	Trenutačna brzina vozila			
	Minimalna [km/h]	Maksimalna [km/h]	Srednja [km/h]	Stand. odstupanje [km/h]
km 82/2	20,00	141,00	68,56	22,77
km 73/10	21,00	130,00	57,76	19,21
km 68/8	19,00	127,00	60,80	17,69
km 60/10	13,00	128,00	56,11	20,18




Na analiziranim je lokacijama prosječna trenutna brzina vozila iznosila 60,07 km/h, dok je standardno odstupanje iznosilo 20,21 km/h. Definirana je formula za predviđanje ekvivalentne buke po kategorijama vozila, a na bazi trenutne brzine vozila. Ta je formula prikazana u tablici 7. gdje vrijednost  $S$  predstavlja trenutnu brzinu vozila u km/h. Drugi član je pozitivan u svim jednadžbama iz tablice 7. To znači da u svim kategorijama vozila povećanje trenutne brzine dovodi i do odgovarajućeg porasta ekvivalentne razine buke.

Tablica 7. Jednadžbe za definiranje buke vozila iskazane po kategorijama vozila

Kategorija vozila	Jednadžba za definiranje buke vozila
Vozila s dva kotača	$Leq = 73,29 + 0,040 \cdot S$
Vozila s tri kotača	$Leq = 72,80 + 0,082 \cdot S$
Osobni automobili, terenska vozila, monovolumeni	$Leq = 73,01 + 0,095 \cdot S$
Autobusi	$Leq = 76,50 + 0,101 \cdot S$
Kamioni	$Leq = 78,37 + 0,109 \cdot S$
Tegljači s prikolicom	$Leq = 76,58 + 0,184 \cdot S$
Leq – ekvivalentna razina buke u dB(A); S – trenutna brzina vozila u km/h	

### 5.3. Dijagrami raspršenosti podataka

Dijagrami raspršenosti podataka, tj.  $P_t$  u odnosu na  $Leq$ ,  $S_t$  u odnosu na  $Leq$ ,  $S_o$  u odnosu na  $Leq$ ,  $T_a$  u odnosu na  $Leq$ ,  $T_s$  u odnosu na  $Leq$ ,  $H$  u odnosu na  $Leq$  i  $Q$  u odnosu na  $Leq$ , izrađeni su da bi se ispitala moguća veza između pojedinačnih parametara na ekvivalentnoj razini buke. Ti su dijagrami prikazani na slikama od 2 do 8.




Slika 2. Odnos između postotka vozila na dva kotača ( $P_t$ ) i ekvivalentne razine buke ( $Leq$ )

Sa slike 2. vidljivo je da se razina ekvivalentne buke povećava usporedno s povećanjem postotka vozila na dva kotača. To dokazuje da ekvivalentna razina buke raste kada u prometu sudjeluju vozila s dva kotača, i to ne samo na cestama s jednim kolnikom, već i na četverotračnim cestama s odvojenim kolnicima.




Slika 3. Odnos između prosječne trenutne brzine vozila na dva kotača ( $S_t$ ) i ekvivalentne razine buke ( $Leq$ )

Slika 3. prikazuje odnos između prosječne trenutne brzine vozila na dva kotača i ekvivalentne razine buke, pri čemu ekvivalentna razina buke raste s porastom prosječne trenutne brzine vozila na dva kotača. To je dokaz da porastu ekvivalentne razine buke doprinosi ne samo broj vozila na dva kotača već i njihova trenutna brzina.




Slika 4. Odnos između prosječne trenutne brzine svih vozila osim vozila na dva kotača ( $S_o$ ) i ekvivalentne razine buke ( $Leq$ )

Sa slike 4. vidljivo je da se razina ekvivalentne buke povećava usporedno s porastom prosječne trenutne brzine svih vozila osim vozila na dva kotača. Dakle, porast trenutne brzine svih vozila dovodi do porasta ekvivalentne razine buke.




Slika 5. Odnos između vanjske temperature ( $T_a$ ) i ekvivalentne razine buke ( $Leq$ )

Na slici 5. vidi se promjena ekvivalentne razine buke u ovisnosti o vanjskoj temperaturi. Može se uočiti da se razina buke smanjuje usporedno s povećanjem vanjske temperature.



Slika 6. Odnos između temperature na površini kolnika ( $T_s$ ) i ekvivalentne razine buke ( $Leq$ )

Slika 6. prikazuje odnos između temperature na površini kolnika i ekvivalentne razine buke. Ekvivalentna buka raste pri nižim temperaturama na površini kolnika. S druge strane, povećanje temperature na površini kolnika dovodi do smanjenja buke. Pri nižim temperaturama kolnika, površina kolnika ima veću količinu vlage što pri kontaktu s gumama vozila uzrokuje veću buku. Stoga se može zaključiti da povećanje temperature na površini kolnika dovodi do smanjenja ekvivalentne razine buke.




Slika 7. Odnos između relativne vlage ( $H$ ) i ekvivalentne buke ( $Leq$ )

Odnos između relativne vlage i ekvivalentne razine buke prikazan je na slici 7. Može se uočiti da se ekvivalentna razina buke povećava usporedno s povećanjem relativne vlage. Povećanjem relativne vlage povećava se i količina vlage u zraku na površini kolnika, što dovodi do veće ekvivalentne razine buke.

Slika 8. prikazuje odnos između ukupnog broja vozila i ekvivalentne razine buke. Očito je da se razina buke povećava usporedno s porastom broja vozila. Međutim u tom dijagramu vidimo da se ekvivalentna razina buke smanjuje usporedno s povećanjem ukupnog broja vozila. Naime, razina buke se očitava u trenutku kada vozilo prolazi pored uređaja za mjerenje zvuka. Na primjer, ako vozilo s dva kotača, automobil

i kamion prolaze istovremeno, tada se očitava maksimalna razina buke koju generira dominantno vozilo. U tom je slučaju nemoguće odrediti udio buke za svaku vrstu vozila. Međutim, broji se ukupan broj vozila koja prolaze kroz mjernu točku. Zbog toga dolazi do ovakvih razlika, a može se i zaključiti da je na dotičnim lokacijama veći postotak vozila koja su upravo u fazi pretjecanja. Ova bi se razlika mogla poništiti kada bi vozila prolazila jedna za drugima, što je praktički nemoguće postići na četverotračnoj autocesti s dva kolnika.



Slika 8. Odnos između ukupnog broja vozila ( $Q$ ) i ekvivalentne razine buke ( $Leq$ )

Tijekom mjerenja uočena je još jedna zanimljivost: razina buke koju proizvode vozila na dva kotača, a naročito mopedi tipa TVS 50, veća je od 80 dB(A). Ovdje do povećanja buke dolazi zbog glasnoće ispušnih Ionaca. Naime, u Indiji su mopedi tipa TVS 50 konstruirani tako da mogu nositi velike terete prilično velikom brzinom. Da bi mogli nositi takve terete i istodobno snažno ubrzavati, napravljene su preinake na ispušnim sustavima koji tako preinačeni stvaraju veću buku. U većini slučajeva, buka koju proizvode takvi mopedi bitno je veća od buke koju proizvode moderni automobili pa čak i višeosovinski autobusi.

## 6. Zaključak

Model za predviđanje ekvivalentne razine buke izveden je na temelju podataka prikupljenih u uvjetima neprekinutog toka prometa po četverotračnoj autocesti. Za izradu modela korišten je program DATAFIT. Obavljena je i ocjena prilagodbe da bi se odredila razina prihvatljivosti tog modela. Ovo istraživanje omogućilo je izvođenje sljedećih zaključaka:

- Multilinearna regresijska jednadžba za predviđanje ekvivalentne razine buke ( $Leq$ ) izvedena je pomoću sljedećih parametara: ukupan broj vozila ( $Q$ ), postotak vozila s dva kotača ( $P_2$ ), trenutna brzina vozila s dva kotača ( $S_2$ ), trenutna brzina ostalih vozila ( $S_o$ ), vanjska temperatura ( $T_a$ ), temperatura na površini kolnika ( $T_s$ ) i relativna vlaga ( $H$ ). Ustanovljeno je da je postotak razlika između očitanih i izračunanih veličina praktički zanemariv.
- Ustanovljeno je da za ovu jednadžbu koeficijent korelacije  $R^2$  iznosi 0,809. Vrijednost  $R^2$  može se poboljšati uključivanjem varijacija, tj. analizom većeg broja nizova podataka s raznih lokacija u različitim vremenskim intervalima.

- Za vrijeme određivanja pogodnosti jednadžbe, u obzir je uzeta nulta hipoteza  $\mu = 0$ , tj. slučaj kada je srednja vrijednost razlika između parova očitanih i predviđenih vrijednosti buke jednaka nuli. Rezultati hi-kvadrat testa s petpostotnom razinom važnosti pokazuju da je nulta hipoteza prihvatljiva, tj. da je srednja vrijednost razlike između očitanih i predviđenih razina buke jednaka nuli.
- Predviđeni model pokazuje vrlo nizak postotak greške pri provjeri podataka (tj. za podatke očitane na petoj lokaciji). Stoga se ovaj model može koristiti za predviđanje razine buke na sličnim cestovnim prometnicama u Indiji.

Provedena mjerenja omogućila su kreiranje izraza za predviđanje buke po kategorijama vozila, bazirana na trenutačnoj brzini. Također su detaljno analizirani odnosi ključnih parametara:  $P_t$  – Leq (postotka vozila na dva kotača i ekvivalentne razine buke),  $S_t$  – Leq (prosječne trenutačne brzine vozila na dva kotača i ekvivalentne razine buke),  $S_o$  – Leq (prosječne trenutačne brzine svih vozila osim vozila na dva kotača i ekvivalentne razine buke),  $T_a$  – Leq (odnos između vanjske temperature i ekvivalentne razine buke),  $T_s$  – Leq (odnos između temperature na površini kolnika i ekvivalentne buke),  $H$  – Leq (odnos između relativne vlage i ekvivalentne buke) i  $Q$  – Leq (odnos između ukupnog broja vozila i ekvivalentne razine buke).

## LITERATURA

- [1] Ozer, S.; Yilmaz, H.; Yesil, M.; Yesil, P.: Evaluation of noise pollution caused by vehicles in the city of Tokat, Turkey, Scientific Research and Essay, 4 (2009), pp. 1205-1212.
- [2] Gundogdu, O., Gokdag, M., Yuksel, F.: A traffic noise prediction method based on vehicle composition using genetic algorithms, Applied Acoustics 6 (2005), pp. 799-809.
- [3] Yilmaz, G., Hocanli, Y.: Mapping of Noise by using GIS in Sanliurfa, Environmental Monitoring and Assessment 121 (2006), pp. 103-108.
- [4] Pamanikabud, P.; Tansatcha, M.; Brown, A.L.: Development of a highway noise prediction model using an Leq 20s measure of basic vehicular noise, Journal of Sound and Vibration 316 (2008), pp. 317-330.
- [5] Alam, J.B., Rahman, M.M., Dikshit, A.K., Khan, S.K.: Study of traffic noise level of Sylhet by multiple regression analysis associated with health hazards, Iran Journal of Environmental Health Science Engineering 3 (2006), pp. 71-78.
- [6] Alam, M.D., Rauf, A.F.M.A., Ahmed, M.F.: Traffic induced noise pollution in Dhaka city. Journal of Civil Engineering, The Institution of Engineers, Bangladesh 29 (2001), pp. 55-63.